第 42 卷 第 4 期
2024 年 12 月

天 文 学 进 展
PROGRESS IN ASTRONOMY

Vol. 42, No. 4
Dec., 2024

doi: 10.3969/j.issn.1000-8349.2024.04.10

Deep-Dark-Net：一种基于生成对抗网络的导星相机暗流预测模型

曲伯桓[1]，杨贺珺[2,3]，何宇轩[1]，郭远昊[1]，刘 宇[1]，曹子皇[3,5]，齐朝祥[4,5]，于 涌[4,5]，王培培[3,5]，赵永恒[3,5]，张 勇[3]，王淑青[3]，栗 剑[3]，吕冠儒[3]，曹兴华[3]，向 铭[3]，邱虹云[6]

(1. 大连理工大学 国际信息与软件学院，大连 116620； 2. 北京工业大学，北京 100124； 3. 中国科学院 国家天文台，北京 100191； 4. 中国科学院 上海天文台，上海 200030； 5. 中国科学院大学，北京 100049； 6. 光速视觉（北京）科技有限公司，北京 102206)

摘要： 暗流会影响图像质量、降低星像的信噪比，进而影响星像位置和流量测量的精度，因此需要在天文数据处理中准确估计并去除暗流。LAMOST 导星图像处理的需求为：在无暗场图像情况下高精度处理历史导星图像数据，简化导星相机暗场图像拍摄的步骤，可以利用导星图像的特性反演和生成高精度可靠的暗场图像。利用 LAMOST 导星原始数据的特性，提出一种基于生成对抗网络模型来精确估计暗流的新方法——Deep-Dark-Net。该方法利用条件生成对抗网络，构建导星图像 Overscan 区域、Optical Black 区域与对应的有效成像区域噪声之间的关联模型，从而通过这些区域反演和重构高精度暗场图像。实验表明：Deep-Dark-Net 预测的暗流与真实暗流的符合度高于传统方法，满足了 LAMOST 望远镜导星图像处理对暗场图像的需求。该工作不仅为天文图像暗流的处理提供了一种新思路、新方法，也为深度学习技术在天文图像处理中的潜在价值和应用方向提供了重要的视角和示例。

关 键 词： 暗流；深度学习；条件生成对抗网络；Deep-Dark-Net；LAMOST

中图分类号： TP317.4, P111.21 **文献标识码：** A

1 引 言

郭守敬望远镜（即大天区面积多目标光纤光谱天文望远镜，Large Sky Area Multi-Object Fiber Spectroscopy Telescope，LAMOST）的导星系统对于保障望远镜的观测效率和质量至关重要，它涉及对机架方位角、高度角、焦面转角和焦距的精确测量，误差的精确

收稿日期： 2024-02-02； **修回日期：** 2024-05-08

资助项目： 国家自然科学基金 (12073047)

通讯作者： 曹子皇，zhcao@nao.cas.cn

计算以及发送误差修正量到相关控制系统。其核心任务是利用导星相机拍摄图像，通过图像处理、星象识别与匹配、星象质心测量及误差方程的解算来获得必要的数据。随着技术的发展，LAMOST 的导星相机已升级到第二代，其感光区域是原来的 4 倍，视场 (field of view, FOV) 得到显著提升，并且导星相机的数量从 4 台增加到 8 台。新一代的硬件系统促使 LAMOST 开发了更为先进的第二代天体测量支持系统，以提高天体测量的精度，支持星像点扩散函数测量和测光，以及增加大气透过率、像质和焦面姿态的测量。导星相机的暗流包含感光器件的热噪声、自身读出噪声以及外围放大电路的读出噪声，这些噪声会显著降低天体图像的信噪比和数据分析的准确性。关于暗流，传统的解决方法是拍摄并计算出一张反映暗流分布的“中值”图像，即暗场图像；然后在数据处理过程中，将每幅待测图像都减去这张暗场图像。尽管这种方法在长期的天文观测中被广泛验证了有效性，但由于 LAMOST 导星相机的硬件差异，部分相机不支持暗场拍摄功能，使得暗场图像的拍摄过程变得繁琐。此外，由于 LAMOST 导星相机的历史数据不包含暗场图像，需要找到一种方法精确反演出暗场图像，以支持高精度的数据处理。

近年来，深度学习技术在天文学领域得到了广泛应用。George 和 Huerta[1] 率先使用深度卷积神经网络来检测引力波信号；Akeret 等人[2] 使用 U-Net 网络来识别并减弱时频图中的射频干涉信号；Ruhe[3] 总结了机器学习在成像切伦科夫和中微子天文学中的应用；陶一寒等人[4] 概述了深度学习在天文学中应用。在深度学习领域，GAN (generative adversarial network) 中生成器和判别器的相互竞争，可以有效地学习数据分布，在模拟和理解复杂数据分布并生成近似真实的图像方面体现出独特优势[5]。在天文学领域，GAN 在处理复杂天文数据方面展示了巨大潜力，例如 Geyer 等人[6] 利用 GAN 生成了大量的射电星系图像训练数据。随着 cGAN (conditional generative adversarial network) 的兴起[7]，图像生成的内容实现了可控，即 cGAN 可以通过在模型输入中引入额外的条件变量生成特定的输出，如输入一幅特定图像，cGAN 可以生成一幅与其内容相关的图像。这种机制不仅增强了生成模型的灵活性，也提高了生成结果的准确性和多样性[8–11]。这些研究不仅证明了深度学习在天文学中的广泛适用性，也为 LAMOST 导星相机的暗流预测和暗场图像反演工作提供了宝贵的参考和启示。

本文的结构如下。第 2 章详细介绍了相关的原理和方法，涉及导星相机传感器的暗电流特性、导星相机原始数据的结构、暗场图像的拍摄以及图像的预处理流程；此外，此章还深入探讨了 Deep-Dark-Net 模型的网络结构和损失函数设计，为理解模型的工作原理和优化策略奠定了坚实的基础。第 3 章详细描述了实验设计及其结果，包括用于训练和测试模型的数据集，模型训练和测试的参数配置，以及实验结果的对比和消融实验；这些实验结果验证了 Deep-Dark-Net 模型在预测和反演暗场图像方面的有效性与可靠性。第 4 章总结了本研究的成果，并对未来的相关研究方向进行了展望。

2　原理及方法

2.1　导星相机传感器的暗电流特性

暗电流 (dark current) 是 CCD 的重要参数，其产生原因简要概括如下：光电效应在半导体材料内产生的电子-空穴对如果不及时分开，过一段时间会重新结合，因此需要在门极上加偏置电压；在偏置电压的作用下，半导体材料内的空穴会被驱离形成耗尽层，这是一个对带负电荷的电子来说势能特别低的区域，因此电子会积累在这个区域内，叫做“势阱”；在 CCD 正常曝光的过程中，暗电流和光电子同时累积在势阱里。暗电流会让噪声增加，同时还占用了存储有效信号的空间，这两方面的共同作用对图像的信噪比产生负面影响。如公式 (1) 所示，在无光子的情况下，半导体内部暗电流的噪声强度与温度和积分时间有关：

$$\delta_{\mathrm{dark}} = \sqrt{I_{\mathrm{d}}t} \quad , \tag{1}$$

式中，δ_{dark} 为暗电流噪声强度，I_{d} 是暗电流，t 为积分时间。

从微观层面看，CCD 暗流的水平主要受半导体材料和制造工艺的共同影响，其来源主要包括：基板材料通电后产生的热电荷，硅与其氧化物之间的区域通电后产生的热电荷和势阱产生的热电荷。从宏观层面看，CCD 暗流的水平主要受到 CCD 工作温度的影响。图 1 显示了 LAMOST 导星相机使用的柯达 KAF-4320 CCD 的暗流和温度的相关性。从图中可以看出，通常情况下，CCD 的暗流水平随制冷温度降低而减少，这种减少在一定范围内呈现近似线性关系，暗流减半的温度间隔为 6.4°C。以导星 CCD 典型工作条件为例：制冷温度为 −15°C，曝光时长 30 s，理论上每个像素暗流约为 240 个电子。

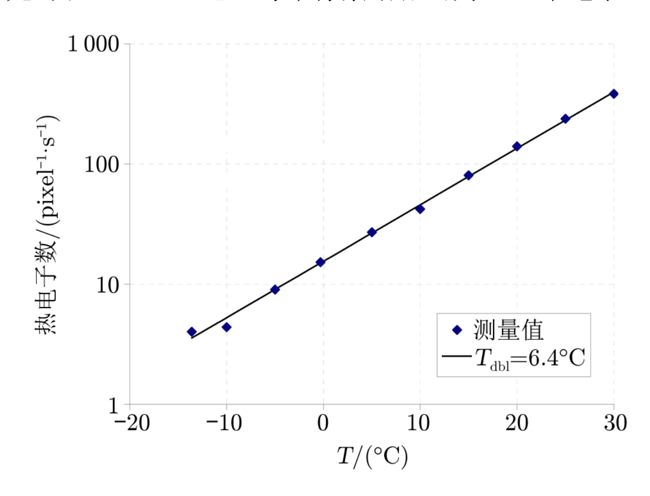
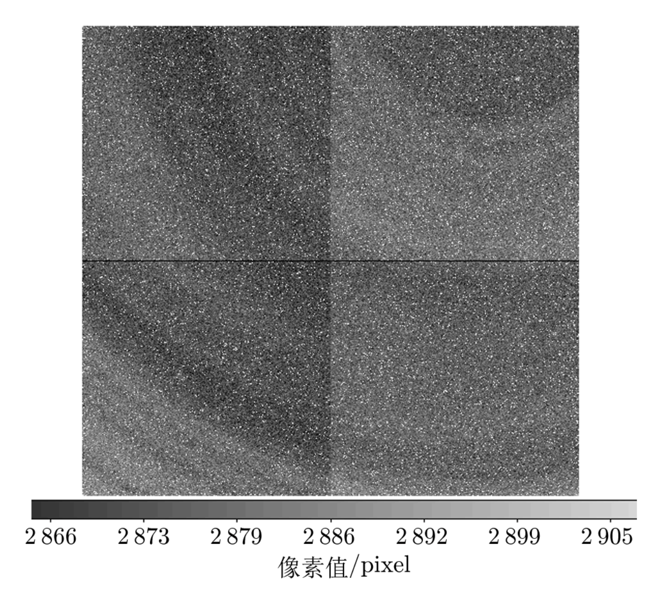


图 1　LAMOST **导星相机传感器** (KAF-4320) **的暗流和温度的关系（来自于柯达公司）**

我们观察到，由于制造工艺的差异，传感器暗电流的分布呈现不均匀性。为了更直观地展示这一效应，在环境温度为 17.6°C，且未进行制冷处理的条件下，我们使用导星相机进行了 10 min 的暗场图像拍摄。图像经过 DS9 软件的 ZScale 对比度拉伸处理后，如图 2

所示，可见明显的同心环状分布。这种暗流分布模式源于 CCD 在制造过程中经历的化学机械抛光 (chemical mechanical polishing, CMP)，与抛光液滴中心位置和研磨路径密切相关。因此，考虑到导星相机 CCD 的这一特性，本文特别强调对暗流的空间分布进行高精度的重构分析。



注：图中的亮点是热噪声，较大尺度的同心环型条纹是由 CCD 制造过程中的化学机械抛光工艺造成的。

图 2 机械抛光工艺造成的暗流分布不均匀

2.2 导星相机原始数据结构

在设计之初，LAMOST 导星相机就注重通过原始图像数据保留探测器及其外围电路的电子学工况和特征。图 3 是相机输出的原始数据复原成二维图像矩阵的情况。可以看到，由于不同的输出原理，图像内部存在几个截然不同的功能区域，这些区域在后期图像的处理过程中对相机性能分析、测试以及各种效应的校正起到重要的作用。以下是对图中各个区域的分析和说明。

(1) A1、A2（深灰色区域）：启动模拟数字转换器 (analog-to-digital converter, AD) 对 CCD 对应通道的行进行数据处理时，多输出的 3 pixel 宽度的数据，“PreScan”区域，包含 AD 自身噪声水平和为进入工作区间电压拉升造成的“污染”信号。

(2) B1、B2（红色区域）：对 CCD 某个通道的某一行进行读出时，CCD 输出的 1 pixel 宽度的无效数据。

(3) C1、C2（蓝色区域）：CCD 行读出前，其内部放大器输出的 4 pixel 的信号，包含 CCD 内部放大器的噪声、上一次行读出残存的信号、外部跟随电路的噪声、AD 的噪声等。

(4) D1、D2（绿色区域）：CCD 四周 4 pixel 宽区域的像素表面被厂商遮蔽（涂黑），被称为“Optical Black”区域，除了不能接收到外部的光子，其物理特性和电器性能均和感光

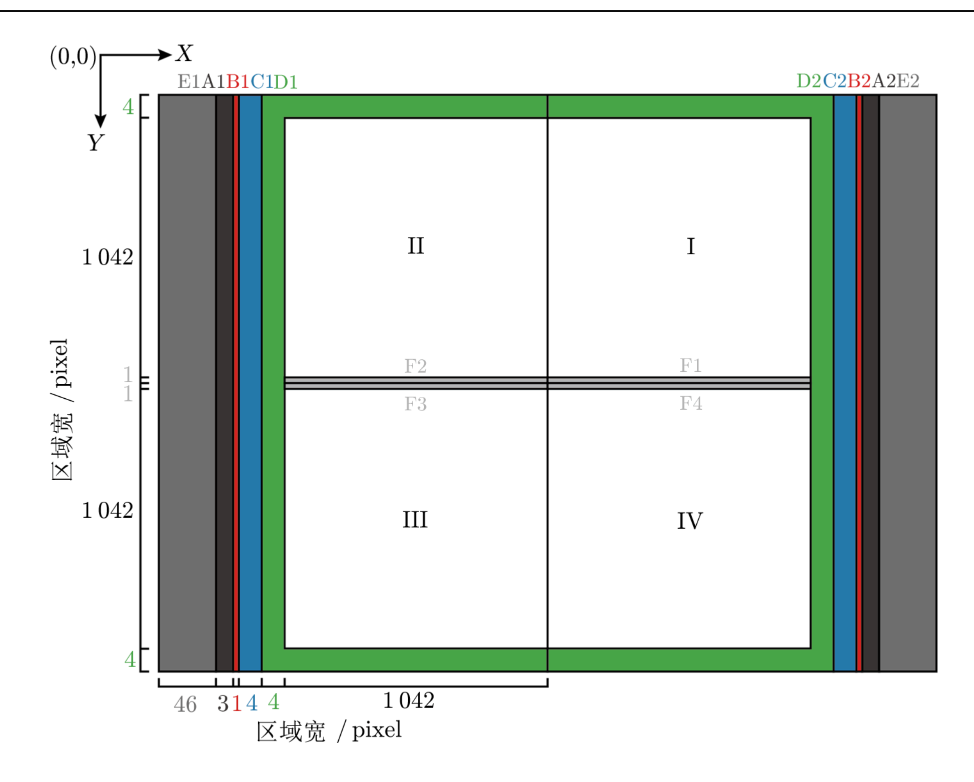


图 3　LAMOST 导星相机原始图像数据的示意图

区域的像素一样。包含 CCD 暗流、CCD 内部放大器的噪声、外部跟随电路的噪声、AD 的噪声等。

(5) E1、E2（灰色区域）：AD 在读完每行 CCD 的像素后，会空读 46 pixel 宽的数据，将其称作“Overscan”区域，该区域包含 AD 自身噪声水平。

(6) F1、F2、F3、F4（浅灰色区域）：由于行数为奇数，导致 LAMOST 导星相机 CCD 的每个通道对中间行都进行了读出，而产生的行数据。这部分数据经过复原和检验，无法可靠地还原中间行物理像素的感光情况，在本工作中全部裁除。

(7) I、II、III、IV （白色区域）：CCD 的有效感光区域，包含所有有效的光电子信号，同时包含 CCD 暗流、CCD 内部放大器的噪声、外部跟随电路的噪声、AD 的噪声等。

2.3　暗场图像的拍摄和图像预处理

导星相机暗场图像的拍摄在 LAMOST 光学实验室的恒温 24°C 无尘间内进行，导星相机的核心与半导体制冷装置分别由两路 12 V 线性电源供电，以提升供电品质。导星相机放在无光的暗箱内，线路引到箱外接到控制机上。相机外接水冷机，其制冷温度设置为 −1°C，这一温度高于理论环境露点温度 5°C，以防止结露；相机靶面的制冷温度设置为 −15°C，与相机在 LAMOST 焦面上工作时的目标制冷温度相同；相机内部的温度控制精度为 ±1°C。

为了满足模型对输入尺寸的需求，我们首先对原始图像（2 200 pixel×2 094 pixel）按不同读出通道进行了分割处理，获得 4 个 CCD 读出通道及对应 AD 各自的子图。接着，

根据 LAMOST 导星相机原始图像数据的示意图（见图 3），将 4 个子图中的有效成像区域图像、Overscan 区域图像和 Optical Black 区域图像分割。每个子图的有效成像区域图像大小为 1 042 pixel×1 042 pixel，Overscan 区域图像大小为 46 pixel×1 042 pixel，Optical Black 区域图像大小为 4 pixel×1 042 pixel（列方向）+ 1 038 pixel×4 pixel（行方向）。我们将 Overscan 区域图像裁剪至 46 pixel×1 024 pixel，作为条件图像 A1；将 Optical Black 区域的列方向裁剪至 4 pixel×1 024 pixel 尺寸，作为条件图像 A2；将 Optical Black 区域行方向剪裁为 1 024 pixel×4 pixel，作为条件图像 A3；将有效成像区域图像裁剪至 1 024 pixel×1 024 pixel，作为目标图像 B。其中 A1、A2、A3 三幅图像使用双线性插值重建至 1 024 pixel×1 024 pixel。这一过程旨在确保图像大小为 2 的整数次幂，以便于模型处理。最后，我们对所有裁剪后的图像进行归一化处理，将 16 位的像素值转换为 0~1 范围内的浮点数，以便于模型的训练和预测。

2.4 Deep-Dark-Net 原理及模型设计

2.4.1 Deep-Dark-Net 模型基本原理

导星相机包含 4 个读出通道，每个通道读出的图像矩阵均包含：导星相机的 CCD 有效成像区域（图 3 中白色区域，标记为 I、II、III、IV）、Overscan 区域（图 3 中灰色区域）和 Optical Black 区域（图 3 中绿色区域）。Overscan 区域能够反映外围电路读出噪声的特征，而 Optical Black 区域可以表征少数图像的感光器件热噪声、感光器件自身读出噪声以及外围放大电路读出噪声的总和。在相机某个输出通道上，AD 的 Overscan 图像和 Optical Black 图像包含的暗流模态与其对应的传感器有效成像区域的暗流模态相关联。在 LAMOST 导星相机的标准工作条件下，即固定的靶面制冷温度和曝光时间，我们利用 Overscan 和 Optical Black 图像来预测对应的有效成像区域的暗流。本算法的核心在于通过模型对大量数据的学习，构建 Overscan 区域、Optical Black 区域与成像区域之间的暗流分布的相关模型。这种方法不仅避免了 LAMOST 在观测前后需单独拍摄暗场图像，从而减少操作的复杂度，而且有助于重构历史图像中的暗流，提高数据处理的精度。此外，由于 Overscan 和 Optical Black 区域的图像包含相机在拍摄时的工作条件，这有助于反演出有效成像区域的暗流随时间的变化。为了解决基于 Overscan 和 Optical Black 区域图像预测对应有效成像区域暗流的问题，我们设计并实践了一种图像到图像映射的技术方案，有效地反映了暗流在图像上的分布特征。

我们采用 cGAN 来构建导星相机 Overscan 区域和 Optical Black 区域与有效成像区域的暗流分布之间的映射关系。以暗场图像中的 Overscan 区域和 Optical Black 区域图像作为输入，使用 cGAN 预测与其对应的成像区域的图像。本研究使用经典的 cGAN 模型——Pix2Pix[12] 作为基础模型，通过构建大量成对的暗流的 Overscan 和 Optical Black 合并后的图像与有效成像区图像驱动模型训练，通过对基础模型的训练过程展开优化，并对模型训练模式进行改进，使模型可以学习特定成像环境条件下（温度、曝光时长）的暗流分布，最终达到精准预测导星相机暗流的目的。我们将这个预测和反演暗场图像的方法称作 Deep-Dark-Net。具体来讲，如图 4 所示，该方法由图像获取和预处理、模型训练与模型应用三个步骤构成。第一步：首先使导星相机在导星工况下拍摄大量的暗场图像，这些图像中

包含特定条件下的暗流；其次，按照预设位置将 Overscan 区域和 Optical Black 区域图像进行裁剪和尺寸归一化；将上述输入图像拼接为一个整体作为模型输入，使有效成像区域的图像作为输出。第二步：在训练阶段，本文基于 U-Net 模型[13]设计了一款生成器，用来合成对应空白输入图像 A 的成像区预测图像 $\hat{B}$，将 $\hat{B}$ 与真实的成像区图像 B 都输入判别器；该判别器本质为一个二分类模型，它始终认为 $\hat{B}$ 为假，同时始终认为 B 为真；通过生成器与判别器的博弈式训练，生成器能够合成与真实图像 B 非常接近、可以“骗过”判别器的图像 $\hat{B}$；本质上，模型通过学习真实图像 B 的分布，来构建输入图像 A 与真实图像 B 之间的映射关系。第三步：在测试阶段，我们将任意导星相机暗场图像作为输入，其中包括 4 个读出通道的 Overscan 区域图像和 Optical Black 区域图像，便可通过训练过的模型预测出接近真实的 4 个读出通道对应的有效成像区域的暗场图像，并与有效成像区域的实际暗场图像进行比较。

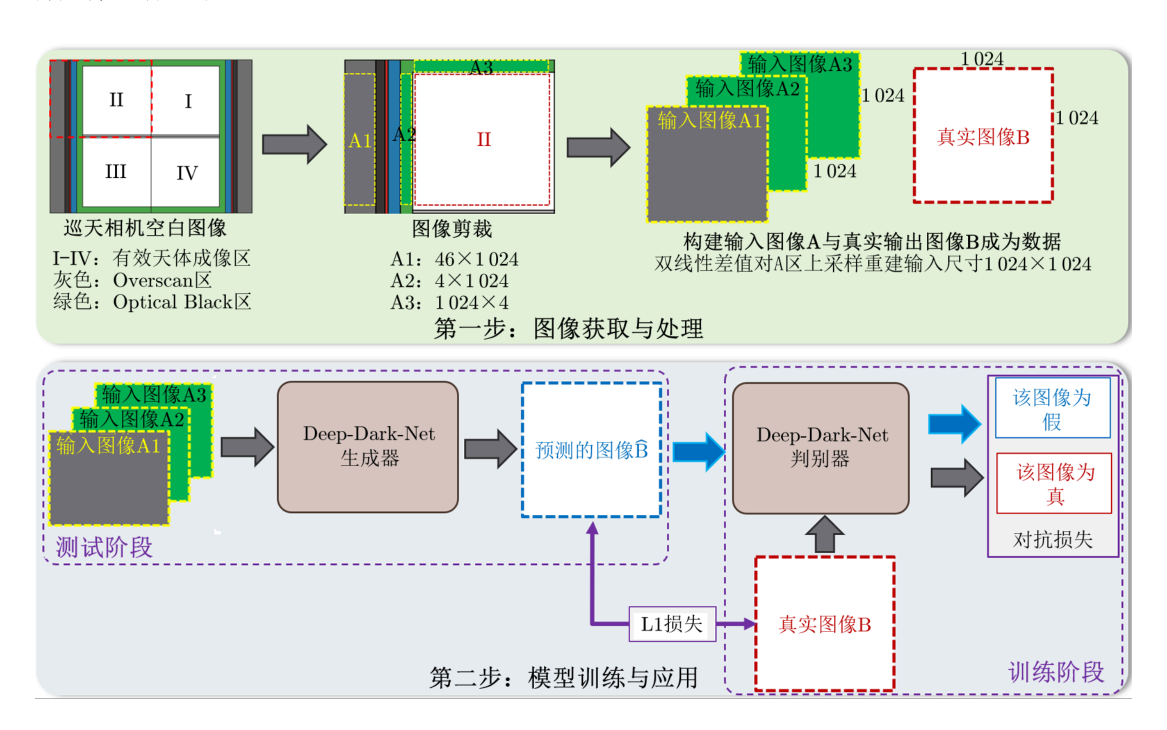


图 4　基本数据处理流程

2.4.2　Deep-Dark-Net 网络架构

Deep-Dark-Net 模型网络架构如图 5 所示，其主要由一个生成器和一个判别器组成。生成器采用改良的 U-Net 结构[13]，整体来讲，该网络由下采样卷积阶段、级联的卷积阶段和上采样卷积阶段三个部分构成，每个卷积层由残差模块[14]实现，并利用跳跃连接策略将下采样阶段的特征[15]与上采样阶段同尺度特征进行连接，提升低层和高层特征的融合效率。具体来讲，输入模块首先将输入图像映射到特征空间，该模块使用反射填充层和一个 7×7 的卷积层对图像进行初步特征提取，继而使用批归一化和 ReLU 激活函数增强特征的非线

性表达。接下来进入类似 U-Net 的特征提取网络，其中下采样卷积阶段使用连续的卷积-下采样操作提取图像不同尺度的特征，上采样卷积阶段使用上采样-卷积操作逐步重建图像特征。本文使用的网络与 U-Net 不同之处在于：(1) 只使用了两次下采样；(2) 第三级特征提取阶段由 9 个级联的卷积层构成；(3) 每个卷积层由残差模块构成，每个残差模块由如下的连续操作实现：反射填充层，$64\times2l$ 维度的 3×3 卷积层，其中 l 表示第 l 个特征提取阶段，以及相应的特征归一化层和 ReLU 激活层。每个下采样卷积阶段输出的特征，通过跳跃连接与上采样卷积阶段中对应尺度的特征进行拼接（图 5 虚线箭头），整体作为相应卷积阶段残差模块的输入，这种经典的特征跳跃连接结构旨在同时保留同尺度的局部特征和上采样得到的高层语义特征。最后，输出层由反射填充和 3×3 卷积层实现，并使用 Tanh 激活函数将输出映射到 0~1 之间。

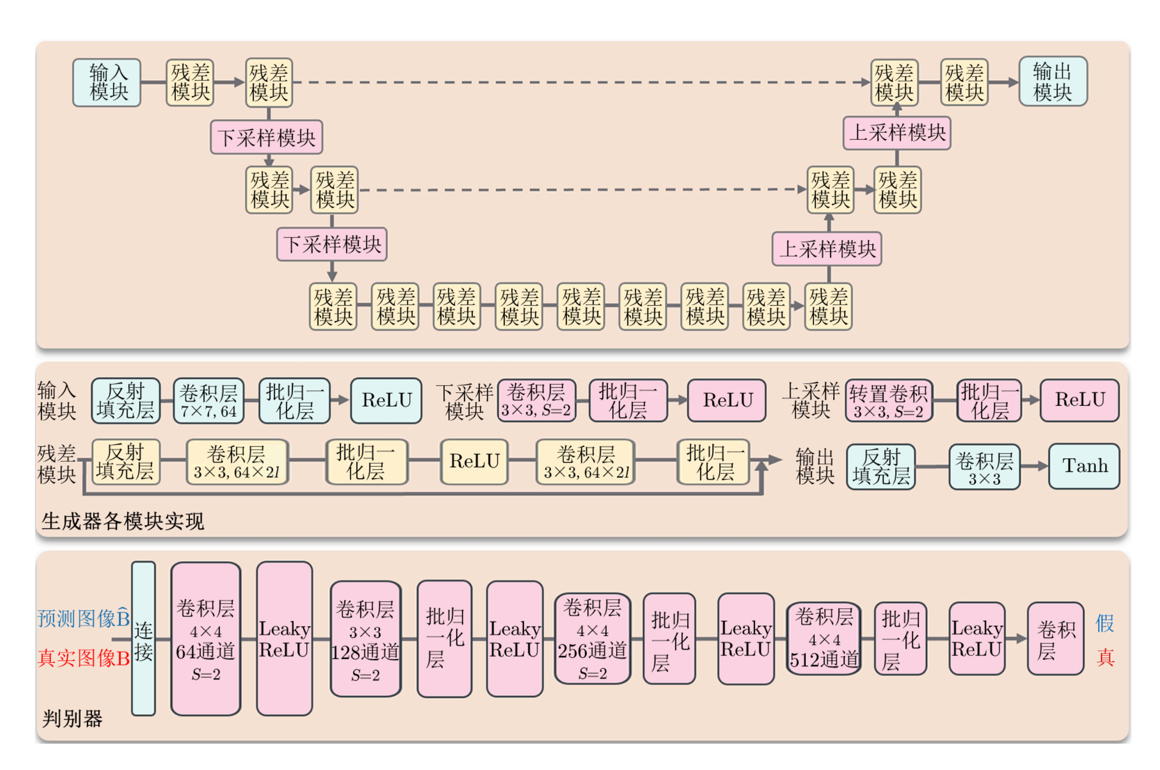


图 5 Deep-Dark-Net 模型网络结构

判别器网络采用一个小型 PatchGAN 分类器实现，其基本原理是将图像分块，生成对应每个图像子块的特征图。在特征图中，每个位置反映了输入图像中对应图像子块属于真实数据的概率。将这些概率值进行平均，可形成一个综合分数，用于判断整个图像的真实性或伪造性。判别器网络结构由三层卷积层、批归一化层和 Leaky-ReLU 激活层构成。除了最后一层卷积层外，该网络每层卷积均使用步长为 2 的 4×4 卷积核；最后一层卷积层步长为 1，以保持输出特征图的尺寸。网络中第一层卷积的输出通道数设定为 64，此后每增加一层，输出通道数翻倍，直到 512。为了在网络中适应不同尺度的特征表示，我们使用批归

一化和 Leaky-ReLU 非线性激活函数来处理层间的输出，Leaky-ReLU 的斜率被设定为 0.2，以增强模型对输入数据中轻微变化的敏感度。

2.5　损失函数

生成对抗网络模型的生成器通过合成近似真实的图像来“骗过”判别器，而判别器尽量识别出合成图像为“假”，通过这样一种对抗训练的方式逐渐提升生成器合成图像的真实性。基于上述分析，本文设计了相应的损失函数驱动模型训练。

设生成器为 G，判别器为 D；设输入图像为 x，对应输入图像 x 的真实图像为 y，生成器的目标是建立输入与输出图像之间的映射 $(G: x \to y)$，设生成器根据输入图像 x 合成的“假”图像为 $\hat{y} = G(x)$。一般对抗损失设计如下：

$$\mathcal{L}_{\mathrm{GAN}}(G, D) = \mathbb{E}_y[\lg D(y)] + \mathbb{E}_x[\lg(1 - D(x, G(x)))] \quad , \tag{2}$$

其中，$\mathbb{E}_y[\lg(D(y)]$ 表示判别器对真实图像的预测结果为真的可能性；$\mathbb{E}_x[\lg(1 - D(x, G(x)))]$ 表示生成器合成的假图像骗过判别器的可能性。

本研究对上述损失函数进行改进。在图像生成任务中，均方根误差 (root mean square error, RMSE) 常用作评价图像重建质量的标准，$RMSE = \sqrt{\frac{\sum_i (y_i - \hat{y}_i)^2}{N}}$，该指标表征了预测图像与真实图像之间像素值的平均差异。首先，我们使用均方误差 (mean square error, MSE) 损失代替公式 (2) 中第一项，同时针对生成器增加 MSE 损失，提升生成器骗过判别器的能力：

$$\mathcal{L}_{\mathrm{GAN}}(G, D) = \mathbb{E}_y[(D(y) - 1)^2] + \mathbb{E}_x[\lg(1 - D(x, G(x)))] + \mathbb{E}_x[(D(x, G(x)) - 1)^2] \quad . \tag{3}$$

其次，本研究采用了成对图像作为输入和输出，也就是每幅输入图像 x，总有一幅真实输出图像 y 对应，因此，我们采用 L1 损失函数确保生成器合成的图像在视觉上与真实图像的一致性（保真性）：

$$\mathcal{L}_{\mathrm{L1}}(G) = \frac{1}{N} \sum_{i=1}^{N} |y_i - G(x)| \quad . \tag{4}$$

最终，我们整合对抗损失和监督损失来驱动模型的训练：

$$G^* = \arg\min_G \max_D \left[\mathcal{L}_{\mathrm{MSE}}(D) + \mathcal{L}_{\mathrm{BCE}}(G) + \mathcal{L}_{\mathrm{MSE}}(G) + \mathcal{L}_{\mathrm{L1}}(G)\right] \quad , \tag{5}$$

其中，$\mathcal{L}_{\mathrm{MSE}}(D) = \mathbb{E}_y[(D(y) - 1)^2]$，　$\mathcal{L}_{\mathrm{BCE}}(G) = \mathbb{E}_x[\lg(1 - D(x, G(x)))]$，　$\mathcal{L}_{\mathrm{MSE}}(G) = \mathbb{E}_x[(D(x, G(x)) - 1)^2]$。在训练过程中，生成器的目标是尽量骗过判别器，使判别器认为生成的图像接近真实，因此损失函数的第一个优化方向是通过训练生成器尽量降低损失。而判别器的目标是尽量将生成器合成的图像判断为假，真实图像判断为真，因此损失函数优化的另一个方向是通过训练判别器尽量增加损失。通过这样一个对抗博弈的训练模式逐渐得到一个强大的生成器。

3 实验及结果

3.1 数据集和实验配置

首先，在 CCD 不同制冷温度下 (−5°C, −10°C, −15°C, −25°C)，我们采集了 20 000 余幅暗场图像，其中 −15°C 为 LAMOST 导星相机日常工作的制冷温度。经过本文设计的预处理流程，构建了一个包含 20 000 幅图像的训练集（其中各温度下拍摄的图像分别为 5 000 幅），以及一个包含 4 000 幅图像的测试集（其中各温度下拍摄的图像分别为 1 000 幅）。在不同温度下分别采集一定数量的图像，主要目的在于确保模型能够在广泛的数据样本上进行学习和适应。这两部分数据集严格分开，确保训练图像之间完全没有重叠，从而保证评估结果的准确性和可靠性。

使用 1 块 NVIDIA GeForce RTX 3090 显卡进行所有模型训练与评测，批次大小设为 1，总的训练 epoch 数设置为 40。采用 Adam 优化器，学习率设定为 0.000 02。

3.2 实验结果对比

我们首先采用传统方法统计训练集 20 000 幅成像区暗场图像的每个像素位置的中值，得到一幅根据训练数据估算的“中值图像”；然后计算测试集中 4 000 幅成像区暗场图像与这幅中值图像的均方根误差。其次，我们采用传统方法统计训练集中不同温度下采集图像的“中值图像”，分别用来计算测试集中不同温度下采集的图像与其温度“中值图像”的均方根误差。最后，使用训练集训练 Deep-Dark-Net 后，针对测试集中 4 000 幅 Overscan 和 Optical Black 图像预测出对应的有效成像区域暗场图像，这相当于针对每个成像区我们都可以获取对应的暗场图像；然后计算测试集中所有预测的暗场图像与真实暗场图像之间的均方根误差，并按照采集温度分别统计均方根误差。如表 1 所示，在全部测试图像上，传统方法的 *RMSE* 值为 43.9，而 Deep-Dark-Net 方法将 *RMSE* 降低至 25.5。这一误差的改进表明，相较于传统的中值法，本文提出的方法可以更加精确地估计导星相机的暗流。

表 1 实验所得的均方根误差 (*RMSE*)

	总	−5°C	−10°C	−15°C	−25°C
传统方法	43.9	39.5	27.9	41.7	13.9
当前方法	25.5	37.8	26.5	23.2	14.5

进一步，我们发现，当 CCD 温度较高时，传统方法和本文提出的方法都对噪声估计增大。这是因为在较高温度下，相机噪声模态的复杂性和噪声水平较大。考虑到在实际应用中往往使用 −15°C 作为标准的成像环境温度，而该温度条件下，本文提出的模型对暗噪声的预测性能超过传统方法，体现出了该方法在实际应用中的优势。

为了深入分析本文方法在图像细节重建方面的性能，我们提出两种可视化技术：热力图和像素差异分布直方图。如图 6 所示，我们在测试集中随机选取了一幅成像区暗场图像，计算它与 Deep-Dark-Net 预测的暗场图像对应像素的绝对误差，即热力图。我们发现，Deep-Dark-Net 预测的暗场图像与真实暗场图像之间的差异较小，像素值差异大多在

15 pixel 以内，而且这些像素值的差异在图像中呈随机分布，表明模型并未在某种模态的噪声上过拟合。

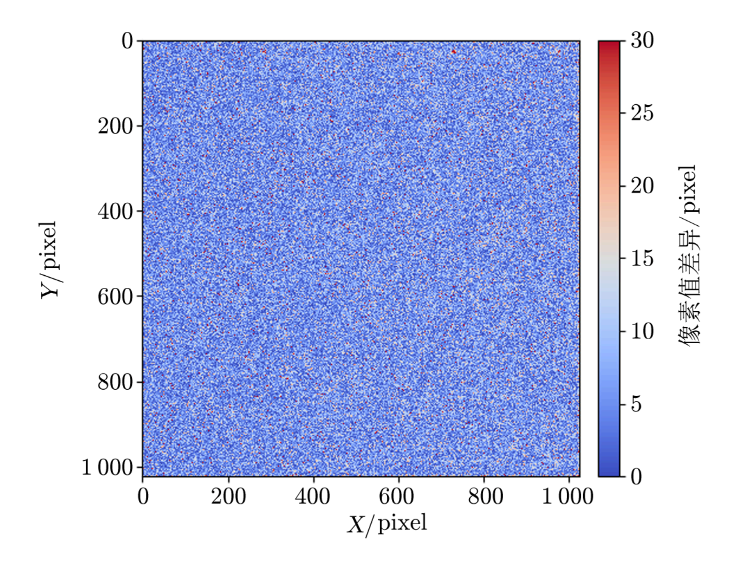


图 6　生成的暗场图像与真实暗场图像之间的像素值差异可视化

如图 7 和图 8 所示，我们分别统计了全部和各温度下的测试集的成像区暗场图像与使用 Deep-Dark-Net 预测的暗场图像之间的像素值差异分布。由图 7 可以看出，超过 90% 的像素值差异在 $-10 \sim 10$ pixel 之间，均值接近 -5 pixel ；直方图的对称性和负偏态也指出，尽管存在一些较大的差异，但整体图像质量的保真度较高，因此尾部较大的像素值差异并不影响我们方法的总体有效性。图 8 显示，不同温度下的像素值差异分布接近，但均值随温度升高而变大，这与前文的分析相符。

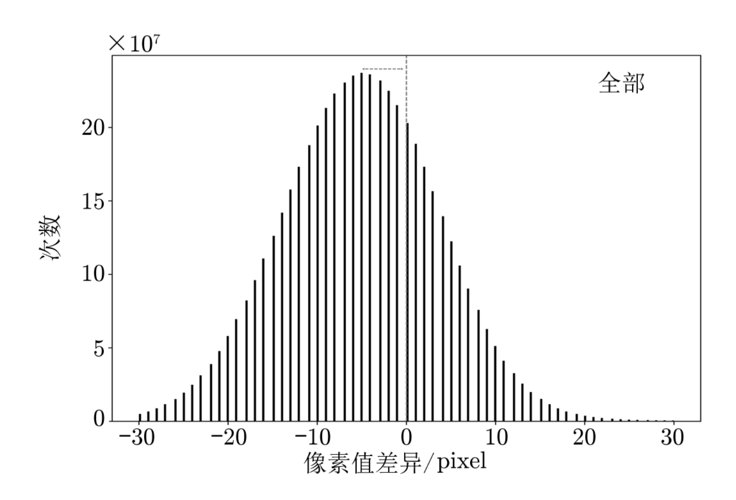


图 7　生成的暗场图像与真实暗场图像之间的像素值差异分布直方图

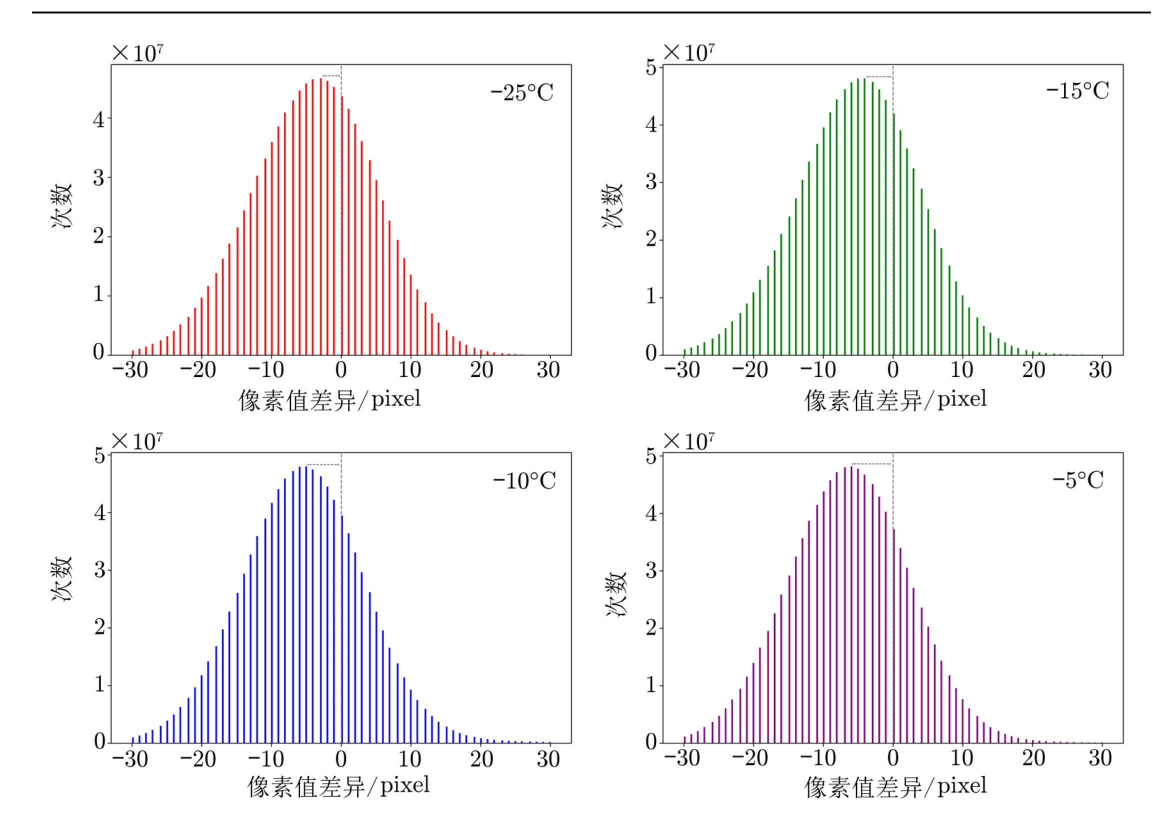


图 8　各温度下生成的暗场图像与真实暗场图像之间的像素值差异分布直方图

3.3　消融实验

在机器学习领域，“消融实验”是一种用于确定模型中特定因素影响力或因果关系的方法，主要用来客观验证机器学习模型的工作原理和特征的重要性。消融实验可以有效证明哪些特征对于模型预测性能的提升起到关键作用，以及在不同情境下如何调整模型结构和参数以改善其性能。此外，消融实验还有助于解释模型的决策过程、提高模型的可解释性。通过消融实验，我们评估影响本文方法预测精度的“损失函数”，具体步骤如下。

(1) 建立初始模型：建立 Deep-Dark-Net。

(2) 操作变量：选择要进行消融实验的不同损失函数，并将其逐一进行验证。

(3) 观察结果：在操作每个变量的情况下，观察模型的输出结果如何变化。

(4) 得出结论：根据观察到的结果，得出关于特定损失函数对模型性能或输出的影响的结论。

我们研究设计了不同损失函数的配置，来评估损失函数每个部分对模型训练性能的影响。在不同配置中，对于生成器，我们始终使用 L1 损失 $\mathcal{L}_{\mathrm{L1}}(G)$ 作为监督式损失。各配置分别为：

配置一，Pix2Pix 模型采用对抗损失形式，即二元交叉熵损失 $\mathcal{L}_{\mathrm{BCE}}(D)+\mathcal{L}_{\mathrm{BCE}}(G)$；

配置二，使用均方误差损失构建对抗损失 $\mathcal{L}_{\mathrm{MSE}}(D)+\mathcal{L}_{\mathrm{MSE}}(G)$；

配置三，使用均方误差损失构建对抗损失中生成器部分 $\mathcal{L}_{\mathrm{BCE}}(D)+\mathcal{L}_{\mathrm{MSE}}(G)$。

为了高效验证不同配置下模型的性能表现，我们在最常用的 CCD 制冷温度 $-15°\mathrm{C}$ 下重新采集并制作了一个训练和测试数据集（其中训练集包含 10 000 幅图像，测试集包含 1 000 幅图像），并使用这个数据集进行本次消融实验。我们使用传统方法统计训练集图像的“中值图像”，并计算测试集图像与该中值图像均方根误差为 20.6，此作为基准性能。实验结果见表 2。

表 2　消融实验结果

实验配置	判别器 D	生成器 G	均方误差
配置一	$\mathcal{L}_{\mathrm{BCE}}(D)$	$\mathcal{L}_{\mathrm{BCE}}(G)+\mathcal{L}_{\mathrm{L1}}(G)$	21.1
配置二	$\mathcal{L}_{\mathrm{MSE}}(D)$	$\mathcal{L}_{\mathrm{MSE}}(G)+\mathcal{L}_{\mathrm{L1}}(G)$	18.7
配置三	$\mathcal{L}_{\mathrm{BCE}}(D)$	$\mathcal{L}_{\mathrm{MSE}}(G)+\mathcal{L}_{\mathrm{L1}}(G)$	26.5
Deep-Dark-Net	$\mathcal{L}_{\mathrm{MSE}}(D)$	$\mathcal{L}_{\mathrm{BCE}}(G)+\mathcal{L}_{\mathrm{MSE}}(G)+\mathcal{L}_{\mathrm{L1}}(G)$	16.9

由表 2 可以得到如下结论。

(1) 使用配置一中 Pix2Pix 模型的原损失函数形式，模型的均方误差为 21.1，暗场图像预测性能甚至略差于传统方法。这表明简单地迁移通用的 cGAN 模型用来预测导星相机暗流性能较差。

(2) 在配置二中，将对抗损失中的交叉损失函数替换为均方误差损失函数后，模型的均方误差降低到 18.7，同时暗流的预测精确度上升；然而，在配置三中，只使用均方误差损失来构建生成器部分的对抗损失，导致模型性能急剧下降。这表明判别器部分的对抗损失函数采用均方误差损失函数，对暗流的预测更加有利。

(3) 在配置二的基础上，Deep-Dark-Net 对判别器部分的对抗损失函数增加了二元交叉熵损失，模型性能进一步提升。这表明对生成器来讲，使用多种形式的对抗损失函数可以提升其合成图像的质量。

综上所述，我们最终确定了最优的损失函数形式。

相比 3.2 节的对比实验结果，本实验仅在 $-15°\mathrm{C}$ 环境下采集的数据上进行评估，Deep-Dark-Net 模型的预测误差从 23.2 进一步降低至 16.9，依然显著优于传统方法的预测误差 20.6。这表明，使用在单一环境下采集的图像来训练模型，可以进一步提升本文方法的性能。

4　总结与展望

针对 LAMOST 导星相机数据处理的需求，我们提出了一种基于生成对抗网络模型精确估计暗流的新方法——Deep-Dark-Net。Deep-Dark-Net 模型避免了传统方法中单独拍摄多张暗场图像来获得暗流中值图像的处理步骤，能够通过导星图像的 Overscan 区域和 Optical Black 区域精确反演，得到对应有效成像区域所包含的暗流图像。对比实验证明，

通过 Deep-Dark-Net 预测的暗流图像精度优于传统方法，这为天文学领域的图像处理提供了一个崭新的方法和思路。下一步研究拟针对不同成像环境和传感器类型的数据进行优化模型的训练，使用该算法全面提升不同成像环境下各种探测器的暗流反演的精度和鲁棒性，推动 Deep-Dark-Net 在多种应用场景中的可用性和准确性。

参考文献：

[1] George D, Huerta E A. Physics Letters B, 2018, 778: 64

[2] Akeret J, Chang C, Lucchi A, et al. Astronomy and Computing, 2017, 18: 35

[3] Ruhe T. International Journal of Modern Physics A, 2020, 35: 2043004

[4] 陶一寒, 崔辰州, 张彦霞, 等. 天文学进展, 2020, 38(2): 168

[5] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Advances in Neural Information Processing Systems. Montreal: NIPS, 2014: 27

[6] Geyer F, Schmidt K, Kummer J, et al. Astronomy and Astrophysics, 2023, 677: A167

[7] Mirza M, Osindero S. arXiv:1411.1784, 2014

[8] Li L H, Jiang L Q, Peng Y F, et al. 2022 International Conference on Technologies and Applications of Artificial Intelligence (TAAI). Taiwan: IEEE, 2022: 54

[9] Sui F, Guo R, Yue W, et al. 2022 IEEE 35th International Conference on Micro Electro Mechanical Systems Conference (MEMS). Tokyo: IEEE, 2022: 450

[10] Herbsthofer L, Ehall B, Tomberger M, et al. Medical Imaging 2022: Digital and Computational Pathology. San Diego, California: SPIE, 2022: 140

[11] Moazami S, Ray D, Pelletier D, et al. IEEE Transactions on Medical Imaging. Buffalo, New York: IEEE, 2023: 1071

[12] Isola P, Zhu J-Y, Zhou T, et al. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, Hawaii: IEEE, 2017: 1125

[13] Ronneberger O, Fischer P, Brox T. Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015, Part III. Munich: Springer, 2015: 234

[14] He K, Zhang X, Ren S, et al. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, Nevada: IEEE, 2016: 770

[15] Jadhav P, Sawal M, Zagade A, et al. 2022 4th International Conference on Inventive Research in Computing Applications (ICIRCA), India: IEEE, 2022: 1489

Deep-Dark-Net: A Survey Camera Dark Noise Prediction Model Based on Generative Adversarial Networks

QU Bohuan[1], YANG Hejun[2,3], HE Yuxuan[1], GUO Yuanhao[1], LIU Yu[1], CAO Zihuang[3,5], QI Zhaoxiang[4,5], YU Yong[4,5], WANG Peipei[3,5], ZHAO Yongheng[3,5], ZHANG Yong[3], WANG Shuqing[3], LI Jian[3], LÜ Guanru[3], CAO Xinghua[3], XIANG Ming[3], QIU Hongyun[6]

(1. International School of Information Science and Engineering, Dalian University of Technology, Dalian 116620, China; 2. Beijing University of Technology, Beijing 100124, China; 3. National Astronomical Observatories, Chinese Academy of Sciences, Beijing 100191, China; 4. Shanghai Astronomical Observatory, Chinese Academy of Sciences, Shanghai 200030, China; 5. University of Chinese Academy of Sciences, Beijing 100049, China; 6. Light Speed Vision (Beijing) Co., Ltd., Beijing 102206, China)

Abstract: The dark current affects image quality, reduces the signal-to-noise ratio of star images, and impacts the accuracy of star position and flux measurements. Therefore, estimating and eliminating dark currents accurately is crucial when processing astronomical data. To meet the demands of LAMOST guide star image processing, this paper proposes a novel method for processing historical guide star images with high precision in the absence of dark field images, simplifying the capture process of dark field images using guide star cameras. Utilizing the characteristics of LAMOST guide star raw data, we introduce a new approach based on a generative adversarial network model, Deep-Dark-Net, to precisely estimate dark current. This method employs a conditional generative adversarial network to construct a correlation model between the Overscan and Optical Black areas of guide star images and their corresponding imaging areas. This model allows inversion and reconstruction of high-precision dark field images through these areas. Experiments demonstrate that the dark current predicted by Deep-Dark-Net aligns more closely with actual dark current than traditional methods, fulfilling the requirements for dark field image processing in LAMOST telescope guide star imagery. This work offers a new approach and methodology for handling astronomical image dark current. It highlights deep learning technology's potential value and application direction in astronomical image processing.

Key words: dark current; deep learning; conditional generative adversarial networks; Deep-Dark-Net; LAMOST